

DOI: 10.7652/xjtuxb201909009

一种采用2级反向传播神经网络的 输电线路故障测距方法

焦在滨^{1,2}, 宋新尧^{1,2}, 李炳绪¹, 吴润东³

(1. 西安交通大学电气工程学院, 710049, 西安; 2. 西安交通大学陕西省智能电网重点实验室, 710049, 西安;
3. 国网安徽省电力有限公司经济技术研究院, 230022, 合肥)

摘要: 针对输电线路的故障测距中过渡电阻及电气量测量误差影响测距精度的问题,提出了一种采用2级反向传播(BP)神经网络的输电线路故障测距方法。通过分析双端电气量随过渡电阻的变化情况,确定了双端电气量变化规律的区域特性,提出了基于过渡电阻分区后在不同区域分别进行精确定位的研究思路。利用第1级网络对双端电气量进行数据融合,将故障场景分为低阻故障和高阻故障,再利用第2级网络中的低阻故障测距网络和高阻故障测距网络分别对低阻故障和高阻故障的双端电气量进行数据融合,计算出精确的故障位置。对训练方法进行改进,在测量电气量中加入高斯白噪声信号来模拟含互感器误差的样本,将无误差样本和含误差样本组成的重复样本对作为训练样本,使训练后的BP神经网络对随机测量误差具备一定的适应能力。电磁暂态仿真结果表明:所提方法不受过渡电阻影响,在高阻故障情况下测距结果的最大误差仍然低于1%,且对随机误差具有较好的适应性,在输入电气量存在一定测量误差的情况下测距结果的最大误差低于2.5%,具有良好的应用前景。

关键词: 输电线路;故障测距;2级反向传播神经网络;过渡电阻;测量误差

中图分类号: TM773 **文献标志码:** A **文章编号:** 0253-987X(2019)09-0061-09

A Fault Location Method for Transmission Line Based on Two-Level Back Propagation Neural Network

JIAO Zaibin^{1,2}, SONG Xinyao^{1,2}, LI Bingxu¹, WU Rundong³

(1. School of Electrical Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. Shaanxi Key Laboratory of Smart Grid, Xi'an Jiaotong University, Xi'an 710049, China;

3. Economic and Technological Research Institute, State Grid Anhui Electric Power Co. Ltd., Hefei 230022, China)

Abstract: Aiming at the problem that transition resistance and measurement error affect the accuracy of fault location in transmission line, a novel method of fault location for transmission line based on two-level back propagation (BP) neural network is proposed. Analyzing the change of the two-terminal electrical quantity with transition resistance, the regional characteristics of the change regularity of the two-level electrical quantity are determined, and the research idea of precise positioning in different regions is introduced. The first level network is used to fuse the two-terminal electrical quantity, and fault scenarios are divided into low-resistance fault and high-resistance fault. Low-resistance fault location network and high-resistance fault location network in the second level network are used to fuse the two-terminal electrical quantity of low-resistance

收稿日期: 2019-03-14。 作者简介: 焦在滨(1976—),男,副教授,博士生导师。 基金项目: 国家重点研发计划资助项目(2017YFB0902900)。

网络出版时间: 2019-06-10

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20190606.1502.008.html>

fault and high-resistance fault respectively, and the accurate fault location is evaluated. Then the training method is improved, white Gaussian noise is added to the measured electrical quantity to simulate the transformer error. The repetitive sample pairs composed of error-free sample and error-containing sample is taken as training sample, so that the trained BP neural network has certain adaptability to the random measurement error. Electromagnetic transient simulation results show that the proposed method is not affected by transition resistance, and the maximum error of fault location is still less than 1% under high-resistance faults. In addition, the method has good adaptability to random errors, and the maximum error of fault location is less than 2% when there are certain measurement errors in the input electrical quantity.

Keywords: transmission line; fault location; two-level back propagation neural network; transition resistance; measurement error

长距离输电线路故障的快速准确定位对于减轻巡线负担、快速恢复故障、保障电力系统的安全运行具有重大意义^[1]。目前的故障测距方法按照原理不同可分为故障分析法和行波法这2类。故障分析法包括阻抗法、解复数方程法和电压法:阻抗法根据测量得到的电压和电流计算阻抗从而得出故障距离,受过渡电阻的影响较大^[2-3];解复数方程法建立电压和电流的复数方程,通过迭代求解方程得出故障距离,计算量较大且容易出现伪根^[4];电压法根据电压沿线路的分布规律求出故障距离^[5]。行波法根据测量观测点和故障点之间的行波传播时间来计算故障距离^[6],虽然具有较高的测距精度,但需要额外投资专门的一次传感器,且应用于高阻故障时可靠性问题较为突出。根据使用到的电气量来源,故障测距又分为单端测距法和双端测距法:单端测距法仅使用单端电气量,存在原理性误差^[7-8];双端测距法可以消除原理性误差,但对同步性的要求较高^[9-10]。过渡电阻是影响故障测距的关键因素,在高阻接地故障下,如阻抗法等的传统测距方法已经失效,解复数方程法、双端测距法等方法虽能够消除过渡电阻的影响,但具有运算较复杂、有伪根、对同步性要求高等不足。

提升测距算法的鲁棒性是故障测距研究的关键问题。鲁棒性是自动控制领域里的一个常用术语,表达在有外界扰动的条件下,系统保持稳定性和其他性能的能力^[11]。国内外学者对各个外界因素的变化对测距方法的影响均展开了深入的研究,例如:线路参数发生变化^[12]、两端数据不同步^[13]、系统运行方式发生改变^[14]等。但是,现有文献均未考虑到电气量数据测量误差对测距结果的影响。在实际电力系统中,测量误差是随机的、客观存在的,无法用统一的表达式进行表示,传统的以解析法为基础的

测距算法无法从原理上将其避免。

神经网络经过充分训练后可以逼近任何期望的数学模型,作为一种新兴智能算法在故障测距领域已有一定的研究。文献[15-16]基于多层次反向传播(BP)神经网络,对单端多维电气量进行数据融合、计算故障位置,但由于未对电气量的变化特性进行充分研究,存在着输入电气量维度大、网络训练复杂、只适用于小电阻故障的不足之处。文献[17]对神经网络的结构进行了研究,提出了适用于故障定位问题的最优网络结构,但文中的训练样本集没有覆盖完整的故障模式空间,仅考虑了小过渡电阻接地的情况,因此训练得到的故障测距模型不能适用于各种故障模式。充分利用神经网络在模式识别及非线性拟合等方面的优势,可以解决现有故障测距方法的诸多不足,提出一种适用于各种故障模式的故障测距神经网络模型具有重要意义。

本文提出了一种基于2级BP神经网络的输电线路故障测距方法。首先,分析了双端电气量随过渡电阻的变化情况;然后,据此将故障场景分为低阻区和高阻区2类,构建了基于过渡电阻分类的2级测距神经网络;最后,对训练方法进行改进,将无误差和考虑误差样本组成的重复样本对作为BP神经网络的训练输入样本,使得训练后的测距网络对随机误差具备一定的适应能力。电磁暂态仿真结果表明:本文方法能够很好地解决高过渡电阻对故障测距准确性的影响,对随机误差的适应能力明显优于已有测距方法。

1 基于重复样本对训练的2级测距BP神经网络

1.1 双端电气量随过渡电阻的变化情况

过渡电阻是故障场景的一个关键属性,也是影响

测距精度的重要因素。对于同一条输电线路,故障位置相同但过渡电阻不同时,两端电气量也会不同。

基于文献[18]中的500 kV典型京津唐输电线路模型及参数,对线路首端5 km处发生各种类型故障时两端故障相电气量随过渡电阻的变化情况进行电磁暂态仿真,结果如图1所示。




图1 各故障类型电气量随过渡电阻的变化情况

由图1可见,输电线路双端电气量的变化规律与过渡电阻直接相关,以单相接地故障为例,可以分析得出以下结论。

(1)在过渡电阻较小(0~50 Ω,以下简称为低阻区)时,随着过渡电阻的变化,电气量变化迅速;在过渡电阻较大(50~300 Ω,以下简称为高阻区)时,随着过渡电阻的变化,电气量变化较缓慢。

(2) n 端故障相电流在低阻区随过渡电阻的增大而减小,在高阻区随过渡电阻的增大而增大,呈现出完全相反的变化规律。

由此可以看出,输电线路双端电气量的变化规律与过渡电阻密切相关,呈现出显著不同的区域性特征。

由图1可知,虽然对于不同故障类型,区分其低阻区和高阻区的阈值不尽相同,但针对所有故障类型,输电线路双端电气量的变化规律均与过渡电阻相关,呈现出明显的区域性特性。为解决过渡电阻对于故障测距精度的影响,本文以过渡电阻为依据构建2级BP神经网络结构,从而实现输电线路的精确测距。

1.2 2级测距BP神经网络的基本原理

对于神经网络,在训练样本的规律过于复杂、训练样本的数目又十分有限的情况下,训练出的神经网络是难以精确反映训练样本的变化规律的。相反,训练样本数据的变化越有规律可循、变化的规律越单一、越简单,则训练网络对样本量的要求越低,训练效果越好。显然,对于一个具有不同变化规律的数据集,如果能够按照其变化规律将该数据集分成若干子类,则对各个子类分别进行网络训练的效果要远远好于对整个数据集进行网络训练的效果。所以,有必要将电气量数据分为高阻区和低阻区2个子类,对各个子类分别进行网络训练,以得到更好的训练效果。

本文构建的两级测距BP神经网络的基本原理如下:将归一化的量测电气量数据输入第1级分区网络进行阻抗分区,根据过渡电阻所在区域选择第2级测距网络,而第2级网络的训练集则分别考虑低阻区及高阻区的故障定位差异,其输出结果即为故障测距的最终结果。

(1)第1级BP神经网络:用于过渡电阻阻抗分区。原始双端电气量(m 端电压和电流 u_m, i_m, n 端电压和电流 u_n, i_n)经预处理后得到归一化的双端电气量,为第1级BP神经网络的输入,输出量 Q_{sort} 表征输入数据位于高阻区或低阻区的概率(若 $Q_{\text{sort}} \leq 0.5$,则输入数据位于低阻区;若 $Q_{\text{sort}} > 0.5$,则输入数据位于高阻区)。第1级神经网络要实现的映射关系为

$$[U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T \rightarrow Q_{\text{sort}} \quad (1)$$

式中: U_m^*, I_m^* 为归一化的 m 端电压、电流; U_n^*, I_n^* 为归一化的 n 端电压、电流; θ_m 为 m 端电压电流相角差; θ_n 为 n 端电压电流相角差。

(2)第2级BP神经网络:用于故障测距。第2级神经网络的输入同第1级神经网络,输出为故障位置 d_0 。第2级神经网络要实现的函数映射关系为

$$[U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T \rightarrow d_0 \quad (2)$$

图2为本文提出的2级BP神经网络的总体结构。在电气量数据输入到神经网络进行计算之前,需要进行线性归一化处理,去除数据的单位限制,将其转化为区间 $[-1, 1]$ 内的数值,便于不同单位或量级的指标能够进行比较和加权。线性归一化的转化函数为

$$x'_i = 2 \frac{x_i - x_{\min}}{x_{\max} - x_{\min}} - 1, \quad (1 \leq i \leq a) \quad (3)$$

式中: x_i 和 x'_i 为某一电气量的原始数据和归一化数据; $x_{\max}$ 为该类电气量数据所有训练样本的最大取值; $x_{\min}$ 为该类电气量数据所有训练样本的最小取值。




图2 2级BP神经网络的总体结构

1.3 重复样本对训练的基本原理

互感器的测量误差是影响电力系统故障测距精度的重要因素。电力系统电压和电流互感器的测量误差与诸多因素相关,具有随机性、不确定性、难以用统一的解析表达式描述等特征,目前的故障测距方法均无法从原理上避免互感器的传变误差对测距结果的影响。

与传统的基于解析法求解的测距算法相比,基于神经网络的测距方法的最大优势在于可以任意调整预期的数学模型,并根据模型选择相应的样本,然后对网络进行训练,使网络精确地逼近预期的数学模型。基于这一点,可以对训练样本做出如下改进:同时输入无误差样本集 A 和考虑误差的样本集 B 。样本集 A 中的数据即为仿真得到的电气量数据真值,样本集 B 中的数据是在样本集 A 的数据中重复性地加入随机噪声(测量误差)后得到的。利用样本集 A 和 B 的数据对神经网络进行训练,使得训练后的神经网络能够自动降低噪声干扰,在无误差和考虑误差的故障场景下均能精确计算故障位置。

对于同一个故障场景,将无误差样本集 A 和考虑误差样本集 B 中的训练样本组成的训练样本集定义为“样本对”。对于某一故障场景,样本对的定义为

$$\left. \begin{aligned} [U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T &\rightarrow d_0 \\ [\hat{U}_m^{(k)}, \hat{I}_m^{(k)}, \hat{U}_n^{(k)}, \hat{I}_n^{(k)}, \hat{\theta}_m^{(k)}, \hat{\theta}_n^{(k)}]^T &\rightarrow d_0 \end{aligned} \right\} \quad (4)$$

式中: $\hat{U}_m^{(k)}, \hat{I}_m^{(k)}, \hat{U}_n^{(k)}, \hat{I}_n^{(k)}, \hat{\theta}_m^{(k)}, \hat{\theta}_n^{(k)}$ 为加入第 k 个测

量误差后的带误差电气量数据。第1个映射关系反映了故障测距模型输入无误差的电气量后,要输出精确的故障距离;第2个映射关系反映了故障测距模型输入有误差的电气量,仍然要输出精确的故障距离。

由于测量误差是随机分布的,对于某一故障场景,仅用1组样本对训练显然是不够的。为了让网络能够充分识别各种测量误差,对于单个故障场景,本文选取的训练样本对的数量为100,重复训练100次,训练的样本对集合为

$$\left. \begin{aligned} [U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T &\rightarrow d_0 \\ [\hat{U}_m^{(1)}, \hat{I}_m^{(1)}, \hat{U}_n^{(1)}, \hat{I}_n^{(1)}, \hat{\theta}_m^{(1)}, \hat{\theta}_n^{(1)}]^T &\rightarrow d_0 \\ [U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T &\rightarrow d_0 \\ [\hat{U}_m^{(2)}, \hat{I}_m^{(2)}, \hat{U}_n^{(2)}, \hat{I}_n^{(2)}, \hat{\theta}_m^{(2)}, \hat{\theta}_n^{(2)}]^T &\rightarrow d_0 \\ \vdots &\vdots \\ [U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T &\rightarrow d_0 \\ [\hat{U}_m^{(k)}, \hat{I}_m^{(k)}, \hat{U}_n^{(k)}, \hat{I}_n^{(k)}, \hat{\theta}_m^{(k)}, \hat{\theta}_n^{(k)}]^T &\rightarrow d_0 \\ \vdots &\vdots \\ [U_m^*, I_m^*, U_n^*, I_n^*, \theta_m, \theta_n]^T &\rightarrow d_0 \\ [\hat{U}_m^{(100)}, \hat{I}_m^{(100)}, \hat{U}_n^{(100)}, \hat{I}_n^{(100)}, \hat{\theta}_m^{(100)}, \hat{\theta}_n^{(100)}]^T &\rightarrow d_0 \end{aligned} \right\} \quad (5)$$

2 训练集的生成与BP神经网络调参

根据电力系统的运行经验,各类短路故障中,单相接地故障所占的比例最大,而且单相接地故障时可能会出现很高的过渡电阻,给准确测距带来较大

的困难。因此,本文以单相接地故障为例,进行神经网络的仿真和训练。该方法同样适用于其他类型的故障。所用系统模型及参数为文献[18]中的京津唐某 500 kV 输电线路模型。线路长度 $L=100$ km, m 端电源的电势标幺值 $\dot{E}_m=1.05\angle 0^\circ$, n 端电源的电势标幺值 $\dot{E}_n=1.00\angle -30^\circ$ 。输电线路的正序和零序等效电路图如图 3 和图 4 所示。图 3 中: Z_{1m} 和 Z_{1n} 分别为 m 、 n 端的正序系统阻抗; R_1 、 L_1 、 C_1 分别为正序电阻、正序电感、正序电容; I_{f1} 为正序故障电流; R_f 为过渡电阻。图 4 中: Z_{0m} 和 Z_{0n} 分别为 m 、 n 端的零序系统阻抗; R_0 、 L_0 、 C_0 分别为零序电阻、零序电感、零序电容; I_{f0} 为正序故障电流。




图3 输电线路正序等效电路图




图4 输电线路零序等效电路图

采用 PSCAD/EMTDC 电磁暂态仿真软件对输电线路模型进行仿真,获得训练的原始数据样本。采用 Matlab 软件进行数据处理,采样频率为 2 kHz,利用全周傅式算法提取工频相量,计算得到双端电压和电流的幅值和相角。

2.1 故障场景的选择

训练样本应涵盖各种故障特征,需要选取合适的、具有代表性的故障场景作为研究对象。生成训练样本时,应考虑以下因素:

- (1) 500 kV 线路上发生故障后,最大的过渡电阻可达 300 Ω ,所以取过渡电阻的区间为 $[0, 300]$ Ω ;
- (2) 故障位置采用归一化后的值,即实际故障位置和线路总长的比值,取值范围为 $[0, 1]$;
- (3) 线路两端电势夹角分别取为 15° 、 25° 、 30° 、 35° 、 45° ;
- (4) 设对端系统阻抗的额定值为 Z_N ,对端系统阻抗取为 $0.8Z_N$ 、 Z_N 、 $1.2Z_N$ 。

考虑到低阻区电气量变化较快,故减小过渡电阻的变化步长,增加故障场景的数量。由于高阻区电气量变化较慢,较少的故障场景即可代表整个高阻区的变化特征。结合上述准则,确定故障场景集合如下。

低阻区:过渡电阻为 $\{0, 5, 10, \dots, 45, 50\}$ Ω ,故障位置为 $\{0, 0.2, 0.4, \dots, 0.8, 1\}$,两端电势夹角为 $\{15^\circ, 25^\circ, 30^\circ, 35^\circ, 45^\circ\}$,对端系统阻抗为 $\{0.8Z_N, Z_N, 1.2Z_N\}$ 。

高阻区:过渡电阻为 $\{60, 80, \dots, 300\}$ Ω ,故障位置为 $\{0, 0.2, 0.4, \dots, 0.8, 1\}$,两端电势夹角为 $\{15^\circ, 25^\circ, 30^\circ, 35^\circ, 45^\circ\}$,对端系统阻抗为 $\{0.8Z_N, Z_N, 1.2Z_N\}$ 。

对于第 1 级的高阻/低阻区域 BP 神经网络,准确分类对确保故障测距模型的精确测距尤为重要。该级神经网络的故障场景集合包含低阻区故障场景集和高阻区故障场景集,期望在低阻区输出量 $Q_{\text{sort}}=0$,在高阻区输出量 $Q_{\text{sort}}=1$ 。

利用选取的样本集训练 BP 神经网络,仿真结果表明训练后的神经网络能够达到以下精度:当过渡电阻 $R \leq 40$ Ω 时,输出量 $Q_{\text{sort}}=0$; $R \geq 60$ Ω 时,输出量 $Q_{\text{sort}}=1$ 。但是,若过渡电阻在 $40 \sim 60$ Ω 的范围内,也就是处于高阻区和低阻区之间的过渡区域时,神经网络计算的 Q_{sort} 在 $0 \sim 1$ 之间。这种无法准确确定所属区域的过渡电阻范围 ($40 \sim 60$ Ω) 称为模糊区,即处于该范围内的过渡电阻可能被分入低阻区,也有可能被分入高阻区。

对于模糊区的处理原则如下:无论第 2 级网络是低阻故障测距网络还是高阻故障测距网络,所选取训练样本的故障场景都应完全覆盖模糊区,即对于处在模糊区内的输入数据,低阻区和高阻区的测距网络都可以给出准确的测距结果。所以,低阻区故障场景的过渡电阻调整为 $\{0, 5, \dots, 55, 60\}$ Ω ,高阻区故障场景的过渡电阻调整为 $\{40, 60, \dots, 280, 300\}$ Ω 。

经过组合,低阻区故障场景数为 1 170 个,高阻区故障场景数为 1 260 个。

2.2 测量误差的模拟

电压互感器和电流互感器的测量误差与其自身的设计参数和系统的运行工况等因素密切相关,目前尚无对互感器误差分布的研究数据,本节仅以互感器测量系统的随机误差为研究对象,说明神经网络训练集的生成原则和方法。

由于测量系统中随机误差的特点是小误差比大

误差出现的概率大、正负误差出现的概率相等、误差的期望值为 0、不同测量误差之间不相关,所以可以认为测量的随机误差为均值为 0 的高斯白噪声^[19]。本文利用 Matlab 软件产生相应的高斯白噪声信号来添加到原始的工频电气量中,将处理后的工频电气量作为考虑测量误差的样本。

为研究加入不同强度白噪声后测量结果误差的分布情况,对某一电气量模拟测量 700 次,每 100 次测量为 1 组并加入相同强度的白噪声,研究该电气量在 7 种不同信噪比下的测量结果误差分布,结果如表 1 所示。

表 1 某电气量在不同信噪比下的误差

某电气量的 信噪比/dB	测量结果平均	测量结果最大
	相对误差/%	相对误差/%
30	2.437	11.289
35	1.425	6.271
40	0.796	2.908
45	0.424	1.567
50	0.289	1.131
55	0.136	0.446
60	0.080	0.307

由于电力系统中保护用电力互感器在系统短路工况下的测量误差一般不超过 5%,根据表 1,本文在该电气量训练样本中加入白噪声后,该电气量的信噪比范围应为 40~50 dB。

2.3 2 级 BP 神经网络的训练

训练前首先需要确定 BP 神经网络的结构参数。BP 神经网络应用最广泛的激活函数有线性激活函数 purelin 函数、对数激活函数 logsig 函数、正切激活函数 tansig 函数。根据文献[17]的研究,用于故障测距的 BP 神经网络的最优结构应具备以下属性:

- (1)输出层采用线性函数;
- (2)其他层采用非线性函数;
- (3)隐含层单元数一般是输入层单元数的 2 倍左右。

本文构建的 2 级 BP 神经网络共包含 3 个 BP 神经网络,根据网络的输入和输出数据的维度,确定 BP 神经网络的基本结构参数为:输入层节点个数为 6,输出层节点个数为 1,隐含层节点个数为 16,输入层激活函数为 tansig 函数,输出层激活函数为 purelin 函数。

在生成的无误差训练样本集上加入白噪声,得

到信噪比为 50 dB 的考虑测量误差的训练样本集,2 级神经网络中的各个网络的训练情况如表 2、表 3 及表 4 所示,表 4 中的绝对误差为实际故障距离与测量故障距离的差,相对误差为绝对误差与输电线路全长的商。

表 2 第 1 级 BP 神经网络的训练参数

参数	数值
训练样本数	144 000
迭代次数	8 461

表 3 第 2 级 BP 神经网络的训练参数

参数	数值	
	高阻区网络	低阻区网络
训练样本数	126 000	117 000
迭代次数	24 213	15 221

表 4 第 2 级 BP 神经网络的训练性能指标

样本类别	指标	数值	
		高阻区网络	低阻区网络
无误差训练样本	平均相对误差/%	0.382	0.309
	最大相对误差/%	0.976	0.849
	最大绝对误差/km	0.976	0.849
加入白噪声的训练样本	平均相对误差/%	1.012	0.991
	最大相对误差/%	2.501	2.192
	最大绝对误差/km	2.501	2.192

对于全部训练样本集,第 1 级 BP 神经网络能够准确地进行分类,误判样本数为 0。误判样本指的是区域神经网络分类结果错误的样本,即本属于低阻区的样本被分类到高阻区,或本属于高阻区的样本被分类到低阻区。对于无误差训练样本集,第 2 级 BP 神经网络故障定位结果的最大相对误差小于 1%;对于含有最大 5%测量误差的训练样本集,第 2 级 BP 神经网络故障定位结果的最大相对误差为 2.5%。由此可知,经过训练后的 BP 神经网络能够准确地逼近训练样本集对应的映射关系,网络的训练效果较好。

3 仿真实验验证

本文提出的 2 级测距 BP 神经网络应实现以下 2 个目标。

目标 1:测距的准确性。输入电气量数据,神经网络经过运算后能够输出准确的测距结果。同时,训练后的神经网络需要对故障场景的变化(如两端

系统阻抗的变化、两端电势夹角的变化等)具备一定的适应能力。此时关注的是神经网络测距的准确性,所以不考虑输入电气量数据有误差的情形,即输入的测试样本数据不含测量误差。

目标 2:测距的鲁棒性。当输入电气量数据中存在一定的测量误差时,测距神经网络仍然能够给出较准确的测距结果。此时输入的测试样本数据应适当的加入测量误差。

本节针对以上 2 个目标,给出具体的仿真验证结果。

3.1 2 级 BP 神经网络测距准确性的验证

本小节是对目标 1 的验证。所选取的测试样本一方面要覆盖各种故障特征,另一方面要与训练样本有差异以便验证神经网络的泛化能力。选取 2 组测试样本如下。

样本 1:过渡电阻为 {8,28,55,70,150,210,270}Ω,故障位置为 {0.1,0.5,0.7,0.9},两端电势夹角为 30°,对端系统阻抗为 1.1Z_N。

样本 2:过渡电阻为 {8,28,55,70,150,210,270}Ω,故障位置为 {0.1,0.5,0.7,0.9},两端电势夹角为 20°,对端系统阻抗为 Z_N。

样本 1 和样本 2 的测试结果如表 5 和表 6 所示。

表 5 样本 1 的测试结果

故障位置 /km	过渡电阻 /Ω	测距结果 /km	测距相对误差 /%	故障位置 /km	过渡电阻 /Ω	测距结果 /km	测距相对误差 /%
10	8	9.99	0.01	70	8	70.02	0.02
	28	9.95	0.05		28	70.05	0.05
	55	10.11	0.11		55	69.94	0.06
	70	10.35	0.35		70	69.73	0.27
	150	9.04	0.96		150	69.97	0.03
	210	9.69	0.31		210	70.11	0.11
50	270	9.84	0.16		270	70.48	0.48
	8	50.05	0.05	90	8	90.05	0.05
	28	50.00	0.00		28	89.97	0.03
	55	49.76	0.24		55	89.68	0.32
	70	49.94	0.06		70	90.44	0.44
	150	50.00	0.00		150	90.11	0.11
	210	50.17	0.17		210	90.16	0.16
	270	50.11	0.11		270	90.22	0.22

根据表 5 可知,在对端系统阻抗发生变化的情

况下,基于 2 级 BP 神经网络的测距方法不受故障位置和过渡电阻的影响,依然可以进行准确地故障测距,故障测距结果最大误差不超过 1%。

表 6 样本 2 的测试结果

故障位置 /km	过渡电阻 /Ω	测距结果 /km	测距相对误差 /%	故障位置 /km	过渡电阻 /Ω	测距结果 /km	测距相对误差 /%
10	8	9.79	0.21	70	8	69.99	0.01
	28	9.81	0.19		28	70.00	0.00
	55	10.25	0.25		55	69.97	0.03
	70	10.48	0.48		70	69.86	0.14
	130	9.45	0.55		130	69.81	0.19
	210	9.64	0.36		210	69.96	0.04
50	270	9.65	0.35		270	69.37	0.63
	8	50.98	0.98	90	8	90.23	0.23
	28	49.39	0.61		28	89.83	0.17
	55	49.73	0.27		55	90.20	0.20
	70	49.97	0.03		70	89.87	0.13
	130	49.99	0.01		130	89.86	0.14
	210	49.23	0.77		210	90.11	0.11
	270	49.48	0		270	89.73	0.27

根据表 6 可知,当两端电势夹角发生改变时,基于 2 级 BP 神经网络的测距方法不受故障位置和过渡电阻的影响,依然可以进行准确的故障测距,故障测距结果最大误差不超过 1%。即使对于高过渡电阻的故障场景,该方法仍然可以保证极高的测距准确度。

3.2 2 级 BP 神经网络测距方法与解析法的鲁棒性比较

选取文献[20]提出的解析法与本文提出的测距方法进行鲁棒性比较。

文献[20]提出了基于解析法求解的数据融合故障测距方法。该方法利用线路两端距离继电器的测距结果和故障录波装置中的电气量数据,采用加权系数的数据融合方法,通过解析求解,对两端距离继电器的测距结果进行数据融合来获得精确的定位结果,仿真结果显示定位结果误差小于 1%。

基于加权系数的数据融合方法建立的数据融合模型为

$$x_{\text{fusion}} = \alpha x_1 + \beta x_2$$

(6)

式中: x_{fusion} 为融合结果; x_1 和 x_2 为距离继电器的双端测距结果; α 和 β 为融合系数。通过解析推导,用

电流表示的融合系数的表达式为

$$\left. \begin{aligned} \alpha &= \frac{1}{1 - \text{Im}(\dot{I}_{tm}/\dot{I}_m)(-\text{Im}(\dot{I}_{tn}/\dot{I}_n))^{-1}} \\ \beta &= \frac{1}{1 - (-\text{Im}(\dot{I}_{tn}/\dot{I}_n)(\text{Im}(\dot{I}_{tm}/\dot{I}_m))^{-1})} \end{aligned} \right\} \quad (7)$$

式中: $\dot{I}_m$ 和 $\dot{I}_n$ 为线路两端的测量电流, 为已知量; $\dot{I}_{tm}$ 和 $\dot{I}_{tn}$ 为线路两端的故障支路电流, 从线路两端计算得到。

采用全线搜索法来确定真实的故障位置, 真实的故障位置是融合误差的唯一极小值点, 融合误差 $E(x)$ 的表达式为

$$E(x) = |x_{\text{fusion}} - x| \quad (8)$$

式中 x 为故障位置到线路 m 端的距离。

用于对比的故障场景参数如下: 过渡电阻为 150Ω , 故障位置为 0.45 , 共测量 100 次, 每次引入不同的随机白噪声作为测量误差, 测量电气量信噪比为 50 dB 。在该故障场景下对比解析法与本文方法的测距相对误差, 结果如图 5 所示。




图5 解析法和本文方法的测距相对误差

由图 5 可知: 在存在一定测量误差的情况下, 利用解析法进行故障测距的误差较大, 最大接近 10% ; 本文方法的测距结果相对误差都在 2% 以内, 鲁棒性明显优于对比方法。

根据仿真验证结果可知, 本文提出的基于重复样本对训练的 2 级 BP 神经网络的测距方法不受过渡电阻的影响, 可以实现高精度的故障定位。另外, 基于重复样本对的训练方法显著提升了测距神经网络的鲁棒性, 即使输入的电气量数据存在一定的测量误差, 仍然能够给出精确的测距结果。

4 结 论

本文提出了基于重复样本对训练的 2 级 BP 神经网络故障测距新方法。在保证测距精度的同时较大地提升了测距算法的鲁棒性, 理论分析和仿真实验表明, 本文提出的测距方法具备以下优点。

(1) 将故障场景根据电气量变化规律分为高阻

区和低阻区两大类, 分别进行神经网络的训练, 在减少训练复杂度的同时提升了测距的精度, 在过渡电阻很高的场景下仍然能够实现精确测距。根据过渡电阻大小进行分类的思想为今后输电线路故障测距的研究提供了新途径。

(2) 由于测量误差的随机性, 以解析法为基础的测距方法无法从原理上将其避免。然而, 神经网络经过充分训练后可以逼近任何期望的数学模型, 利用这一优势, 本文对训练方法作出了改进: 将无误差和有误差样本组成的重复样本对作为 BP 神经网络的训练输入样本, 使得训练后的 BP 神经网络能够在输入的电气量存在一定的测量误差时, 仍然能给出较为精确的测距结果。利用含误差的样本在训练中提升神经网络对随机误差的适应能力, 也是一种提升故障测距精度的新思路。

参考文献:

- [1] 葛耀中. 新型继电保护和故障测距原理与技术 [M]. 西安: 西安交通大学出版社, 2007: 256-335.
- [2] 王宾, 董新洲, 薄志谦, 等. 特高压长线路单端阻抗法单相接地故障测距 [J]. 电力系统自动化, 2008, 32(14): 25-29.
WANG Bin, DONG Xinzhou, BO Zhiqian, et al. An impedance fault location algorithm for UHV long transmission lines with single-line-to-ground faults [J]. Automation of Electric Power Systems, 2008, 32(14): 25-29.
- [3] 郭俊宏, 谭伟璞, 杨以涵, 等. 电力系统故障定位原理综述 [J]. 继电器, 2006, 34(3): 76-81.
GUO Junhong, TAN Weipu, YANG Yihan, et al. Summary on fault location principle in power system [J]. Relay, 2006, 34(3): 76-81.
- [4] 杨铖, 索南加乐, 李亚利. 基于 $R-L$ 模型的单相重合闸线路故障测距方法 [J]. 电力系统自动化, 2010, 34(10): 71-75.
YANG Cheng, SUONAN Jiale, LI Yali. Study on the fault location algorithm based on $R-L$ model for transmission lines with single-pole reclosure [J]. Automation of Electric Power Systems, 2010, 34(10): 71-75.
- [5] 林富洪, 曾惠敏. 基于分布参数模型的高压输电线路单相接地故障单端测距方法 [J]. 电网技术, 2011, 35(4): 201-205.
LIN Fuhong, ZENG Huimin. One-terminal fault location of single-phase to earth fault based on distributed parameter model of HV transmission line [J]. Power System Technology, 2011, 35(4): 201-205.
- [6] 林圣, 何正友, 陈鉴, 等. 基于行波时频特征的单端

- 故障测距方法[J]. 电网技术, 2012, 36(1): 258-264.
- LIN Sheng, HE Zhengyou, CHEN Jian, et al. A single terminal fault location method based on time-frequency characteristic of traveling wave[J]. Power System Technology, 2012, 36(1): 258-264.
- [7] FARSHAD M, SADEH J. Accurate single-phase fault-location method for transmission lines based on k -nearest neighbor algorithm using one-end voltage[J]. IEEE Transactions on Power Delivery, 2012, 27(4): 2360-2367.
- [8] 卢继平, 黎颖, 李健, 等. 行波法与阻抗法结合的综合单端故障测距新方法[J]. 电力系统自动化, 2007, 31(23): 65-69.
- LU Jiwei, LI Ying, LI Jian, et al. Non-communication fault locating of transmission line based on traveling wave and impedance method[J]. Automation of Electric Power Systems, 2007, 31(23): 65-69.
- [9] 索南加乐, 许文宣, 何世恩, 等. 基于双端电气量的串补输电线路故障测距算法[J]. 中国电机工程学报, 2013, 33(19): 157-164, 7.
- SUONAN Jiale, XU Wenxuan, HE Shi'en, et al. A fault location algorithm for series compensated transmission lines based on two-end information[J]. Proceedings of the CSEE, 2013, 33(19): 157-164.
- [10] 毛鹏, 张兆宁, 苗友忠, 等. 基于双端电气量的输电线路故障测距的新方法[J]. 继电器, 2000, 28(5): 24-27.
- MAO Peng, ZHANG Zhaoning, MIAO Youzhong, et al. A novel technique for locating transmission line fault based on the two-terminal electrical quantities[J]. Relay, 2000, 28(5): 24-27.
- [11] 全玉生, 王晓蓉, 杨敏中, 等. 工频双端故障测距算法的鲁棒性问题和新算法研究[J]. 电力系统自动化, 2000, 24(10): 28-32.
- QUAN Yusheng, WANG Xiaorong, YANG Minzhong, et al. Two new algorithms and their robustness for two-terminal fault location on HV transmission line[J]. Automation of Electric Power Systems, 2000, 24(10): 28-32.
- [12] 梁军, 麻常辉, 负志皓. 基于线路参数估计的高压架空输电线路故障测距新算法[J]. 电网技术, 2004, 28(4): 60-63, 68.
- LIANG Jun, MA Changhui, YUN Zhihao. A fault location algorithm for high voltage overhead power transmission line based on line parameter estimation[J]. Power System Technology, 2004, 28(4): 60-63, 68.
- [13] 束洪春, 司大军, 葛耀中, 等. 利用双端不同步数据的高压输电线路故障测距实用算法及其实现[J]. 电网技术, 2000, 24(2): 45-49.
- SHU Hongchun, SI Dajun, GE Yaozhong, et al. Study on practical fault location algorithm for two-terminal HV and EHV transmission lines using asynchronous data at both ends[J]. Power System Technology, 2000, 24(2): 45-49.
- [14] 施世鸿. 高压输电线路故障测距研究[D]. 杭州: 浙江大学, 2008: 47-64.
- [15] 毛鹏, 孙雅明, 张兆宁. 具有冗余神经元神经网络模型系统的输电线路故障测距的研究[J]. 中国电机工程学报, 2000, 20(7): 28-33.
- MAO Peng, SUN Yaming, ZHANG Zhaoning. Study of fault location for high voltage over-head transmission line using neural networks model system with redundant neuron[J]. Proceedings of the CSEE, 2000, 20(7): 28-33.
- [16] CHEN Z, MAUN J C. Artificial neural network approach to single-ended fault locator for transmission lines[J]. IEEE Transactions on Power Systems, 2000, 16(4): 949-950.
- [17] GRACIA J, MAZON A J, ZAMORA I. Best ANN structures for fault location in single- and double-circuit transmission lines[J]. IEEE Transactions on Power Delivery, 2005, 20(4): 2389-2395.
- [18] 索南加乐, 王增超, 张健康, 等. 基于参数识别的高阻接地距离保护算法[J]. 中国电机工程学报, 2011, 31(31): 173-178.
- SUONAN Jiale, WANG Zengchao, ZHANG Jiankang, et al. A novel distance protection algorithm for high resistance grounding faults based on parameter identification[J]. Proceedings of the CSEE, 2011, 31(31): 173-178.
- [19] 王珍意. 电力系统状态估计[D]. 武汉: 华中科技大学, 2005: 8-24.
- [20] 焦在滨, 吴润东, 王钊, 等. 利用数据融合技术提升输电线路故障定位精度的新方法[J]. 中国电机工程学报, 2017, 37(9): 2571-2579.
- JIAO Zaibin, WU Rundong, WANG Zhao, et al. A novel method to improve the fault location accuracy in transmission line based on data fusion technology[J]. Proceedings of the CSEE, 2017, 37(9): 2571-2579.

(编辑 陶晴)